

2. Suradnja

[Metadata, citation and similar](#)

na razvoju inovacija

ZNANSTVENI RAD

Ljiljana Božić *

Sažetak

U svrhu razvoja inovacije, poduzeća mogu surađivati s drugim poduzećima i znanstvenim institucijama, odnosno drugim subjektima koji imaju interes za njeno razvijanje. Suradnja na razvoju inovacija ovisi o više čimbenika. U ovom je radu cilj utvrditi koje su varijable prediktori suradnje hrvatskih poduzeća na razvoju inovacije. Primjenom diskriminacijske analize utvrđeno je da razlikovanju između poduzeća koja surađuju i onih koja nemaju ugovornu suradnju doprinosi pet varijabli: nedostatak kvalificiranog osoblja, broj radikalnih inovacija, visina ulaganja u istraživanje i razvoj, broj zaposlenih i tržišna orijentacija. S druge strane, razlikovanju između skupine poduzeća koja ne surađuju na razvoju inovacija i onih koja surađuju ne doprinose sljedeće varijable: broj inkrementalnih inovacija, visoki troškovi inovacijskih aktivnosti i nedostatak odgovarajućih izvora financiranja.

Ključne riječi: suradnja, inovacija, diskriminacijska analiza

JEL klasifikacija: O31, O32

* Ljiljana Božić, asistentica, Ekonomski institut, Zagreb.

1. Uvod

Razvoj inovacija u suradnji s različitim subjektima česta je pojava u suvremenom poslovanju. Suradnja poduzeća može biti formalnog, ali i neformalnog karaktera. U svrhu razvoja inovacije proizvođa poduzeća uglavnom ugovorom formaliziraju suradnju s drugim subjektima. Takav oblik suradnje omogućava poduzeću pristup resursima kojih nema dovoljno za razvoj novog proizvoda. Istraživanja su pokazala da su suradnji u razvoju inovacija sklonija velika poduzeća, iako suradnja nije isključivo privilegija velikih poduzeća (Trott, 2005). Jedan od razloga zbog kojeg bi suradnji bila sklonija velika poduzeća je pretpostavka da takva poduzeća imaju razvijenije mreže, što im pomaže u uspostavljanju suradnje (Račić, Radas i Rajh, 2004).

U literaturi je poznato postojanje neformalne suradnje, odnosno formiranje neformalnih mreža u razvoju inovacija (von Hippel, 1987). Neformalna je suradnja u razvoju inovacija prisutna u slučajevima kada je opseg potrebne suradnje manji pa vrijednost cijelog posla ne bi opravdala sklapanje ugovora.

Prema jednom od modela inovacija, konkretno modelu matrice upoznatosti, koji su razvili Roberts i Berry (1985), različiti oblici inovacijske suradnje spominju se u kontekstu složenosti inovacije koju poduzeće razvija. Poduzeća su sklonija razvijati radikalne inovacije u suradnji s drugima, dok inkrementalne inovacije razvijaju unutar poduzeća. Ovaj je pristup u skladu s teorijom po kojoj su poduzeća sklonija razvijanju onih inovacija za koje imaju odgovarajuće sposobnosti, odnosno koje su samim time utemeljene na poznatoj tehnologiji (Henderson i Clark, 1990; Abernathy i Clark, 1985). Razvoj radikalnih inovacija zahtijeva usvajanje novih sposobnosti zbog čega se povećavaju mogućnosti za neuspjeh inovacije na tržištu. Rješenje ovog problema Roberts i Berry (1985) nalaze u pravilnom odabiru strategije ulaska u razvoj novog proizvoda. Samostalan razvoj novog proizvoda unutar poduzeća preporučljiv je za inkrementalne inovacije. Što poduzeće manje poznaje tehnologiju i/ili tržište, to je bolje koristiti neki složeniji oblik ulaska u razvoj inovacije.

Suradnja na razvoju inovacija u literaturi se općenito navodi u pozitivnom kontekstu. Iako je suradnja između poduzeća i drugih subjekata poželjna kada se radi o razvoju novog proizvoda, treba imati na umu i opasnosti koje nosi sa sobom. Dadgson (1992) je istaknuo neke od njih. Prvenstveno, u literaturi nalazimo malo podataka o rezultatima suradnje. Ono što se zna jest da suradnja ne mora nužno rezultirati koristima, odnosno da vrlo rijetko dovodi do koristi za sve partnere. Radas (2005) je utvrdila da intenzitet suradnje poduzeća i znanstvenih institucija u Hrvatskoj ne doprinosi povećanju broja patenata niti povećanju prihoda od prodaje novih proizvoda, što upućuje na nesposobnost poduzeća da iskoriste rezultate suradnje. Nadalje, Dadgson (1992) ističe kako suradnja može biti usmjerena stvaranju monopola i voditi smanjenju broja inovacija. Konačno, suradnja u razvoju inovacija nije nužno rezultat snage poduzeća, već njegove slabosti i nedostatka resursa potrebnih za razvoj inovacija.

Hoće li poduzeće inovaciju razvijati u suradnji s nekim od potencijalnih subjekata i s kojim će uspostaviti suradnju ovisi o više čimbenika, a oni su: vrsta tehnologije i tržišta, troškovi razvoja inovacije, sposobnosti potencijalnih suradnika i postojanje komplementarnih sposobnosti (Afuah, 2003). Čimbenici koje je identificirao Afuah na tragu su razloga za suradnju u razvoju inovacije koje je istaknuo Dodgson (1992), a oni su tehnološki razlozi, razlozi vezani za konkurentnost i korporativni razlozi.

Što se tiče inovacijske suradnje u hrvatskim poduzećima, rezultati različitih istraživanja pokazali su da ona nije na zavidnoj razini. Samo je 6 posto hrvatskih poduzeća koja inovacije razvijaju u suradnji s drugim subjektima (Račić, Radas i Rajh, 2004). Također, prema rezultatima tog istraživanja velika poduzeća češće razvijaju inovacije u suradnji s drugim institucijama iz čega autori izvode zaključak o slaboj umreženosti malih poduzeća.

Prema rezultatima istraživanja koje su provele Prester i Podrug (2006) u proizvodnim je poduzećima suradnja s različitim subjektima na visokoj razini. Iznimka od toga je suradnja s konkurentima koja je u nekim industrijama na niskoj razini. Ovakav rezultat je razumljiv s obzirom da je suradnja s konkurentima u razvoju inovacije značajka samo sektora koji su specifični po složenom razvoju inovacije, tako da zahtijeva zajedničko djelovanje konkurenata. Razvoj inovacije je jedan od načina za ostvarivanje prednosti pred konkurencijom.

Važno je napomenuti da su ta istraživanja usmjerena na različite vrste poduzeća iz čega i proizlaze različiti zaključci o inovacijskoj suradnji hrvatskih poduzeća. Naime, Račić, Radas i Rajh (2004) analiziraju mala, srednja i velika poduzeća iz proizvodnog i uslužnog sektora u Hrvatskoj, za razliku od istraživanja u Prester i Podrug (2006) koje je usmjereno isključivo na proizvodna poduzeća.

Imajući na umu različite čimbenike koji utječu na uspostavljanje suradnje s različitim subjektima, kao i specifičnosti hrvatskih poduzeća, cilj je rada utvrditi koje varijable mogu biti prediktori suradnje poduzeća s drugim subjektima u razvoju inovacija.

U ovom se radu ne uzima u obzir subjekt s kojim se surađuje. Cilj je općenito analizirati koje su varijable po kojima se može utvrditi sklonost poduzeća suradnji u razvoju inovacija. U određenim industrijama poduzeća mogu biti sklonija određenom obliku suradnje ili određenoj vrsti subjekta. Međutim, u radu se neće razmatrati razlika s obzirom na pojedinačne specifičnosti poduzeća u pogledu sklonosti suradnji.

Također, u radu se promatra samo postojanje ugovorene, odnosno formalne suradnje s bilo kojim subjektom. Kako je neformalne društvene mreže nešto teže identificirati i istražiti primjenom anketnog upitnika, u radu su u obzir uzete isključivo one koje imaju formalni karakter. Time se nije želio umanjiti značaj neformalne suradnje.

2. Hipoteze istraživanja

U radu se utvrđuje kako osam nezavisnih varijabli razlikuju članove dviju grupa (poduzeća koja surađuju i poduzeća koja ne surađuju s drugim subjektima na razvoju inovacija). Nezavisne se varijable odnose na karakteristike inovacije, karakteristike poduzeća i čimbenike koji otežavaju inovacijske aktivnosti.

Varijable koje se odnose na vrstu inovacije proizvoda – Kako je već spomenuto, odluka poduzeća o uspostavljanju suradnje može biti potaknuta karakteristikama inovacije, tj. njenim stupnjem novosti. Poduzeća teže razvoju inovacija proizvoda u suradnji s drugim subjektima kada su te inovacije visokog stupnja novosti. Radikalne inovacije zbog svoje složenosti i novosti za tržište zahtijevaju više napora i znatnija financijska sredstva, a u isto se vrijeme uz njih veže veći rizik. Zbog toga poduzeća teže uspostavljanju suradnje s drugim poduzećima i institucijama. Razvoj inkrementalnih inovacija je manje složen zbog čega je i potreba za suradnjom manja. Ipak, ne može se potpuno isključiti potreba poduzeća da i u slučaju razvoja inkrementalnih inovacija uspostave neki oblik suradnje. U skladu s tim u diskriminacijsku su analizu uvrštene varijable *broj inkrementalnih inovacija* i *broj radikalnih inovacija* kako bi se utvrdio njihov značaj za diskriminiranje članova u skupinama. Sukladno tome, postavljene su hipoteze H1 i H2.

H1: Postoje razlike između poduzeća koja na razvoju inovacije surađuju s drugim subjektima i onih koja ne surađuju s obzirom na broj inkrementalnih inovacija koje su razvili.

H2: *Postoje razlike između poduzeća koja na razvoju inovacije surađuju s drugim subjektima i onih koja ne surađuju s obzirom na broj radikalnih inovacija koje su razvili.*

Varijable koje se odnose na obilježja poduzeća za koja se pretpostavlja da mogu utjecati na odvajanje članova u jednu od dvije skupine s obzirom na inovacijsku suradnju su *iznos ukupnih ulaganja u istraživanje i razvoj, broj zaposlenih i indeks tržišne orijentacije*. Iznos ukupnih ulaganja u istraživanje i razvoj upućuje na značaj koji se pridaje inovacijskim aktivnostima. Poduzeća koja ulažu visoke iznose u istraživanje i razvoj novih proizvoda veliki značaj pridaju inovacijama pomoću kojih nastoje utjecati na uspješnost svog poslovanja. Zbog toga se u takvim poduzećima može javljati potreba za suradnjom s drugim subjektima.

H3: *Postoje razlike u suradnji poduzeća s drugim subjektima na razvoju inovacije s obzirom na iznos ukupnih ulaganja u istraživanje i razvoj.*

Već je u uvodnom dijelu istaknuto da bi velika poduzeća trebala biti sklonija sklapanju suradnje s drugim subjektima u cilju razvoja inovacije proizvoda zbog razvijenih mreža kojima imaju pristup, zbog čega se varijabla veličine uključuje u diskriminacijsku analizu.

H4: *Poduzeća koja surađuju u razvoju inovacija s drugim subjektima po veličini se razlikuju od onih koja ne surađuju.*

Indeks tržišne orijentacije predstavlja intenzitet poslovne kulture mjereno na MKTOR ljestvici koju su razvili Narver i Slater (1990). Poduzeća koja iskazuju veći stupanj tržišne orijentacije otvorenija su prema svojim potrošačima i kupcima, te drugim subjektima. Osim toga, kontinuirano prate aktivnosti konkurencije i potiču suradnju i zajedničko djelovanje članova svih odjela unutar poduzeća. Otvorenost poduzeća prema vanjskom okruženju može utjecati na sklonost uspostavljanju suradnje s drugim subjektima kada se radi o razvoju inovacije proizvoda.

Treća skupina varijabli obuhvaća tri *varijable koje se odnose na intenzitet djelovanja čimbenika koji otežavaju inovacijske aktivnost*. Naime, poduzeća se pri razvoju inovacija suočavaju s određenim čimbenicima koji otežavaju nesmetan razvoj inovacija. Ti unutarnji i vanjski čimbenici, odnosno njihov intenzitet, mogu ponukati poduzeće da uspostavi ugovornu suradnju s drugim poduzećima i institucijama, i na taj način olakša razvoj inovacije. Otežavajući čimbenici uključeni u diskriminacijsku analizu su: *previšoki troškovi inovacijskih aktivnosti, nedostatak odgovarajućih izvora financiranja za inovacijske aktivnosti i nedostatak kvalificiranog osoblja za inovacijske aktivnosti*.

H7: Nedostatak izvora financiranja za inovacijske aktivnosti doprinosi razlikovanju između poduzeća koja surađuju i onih koja ne surađuju u razvoju inovacija s drugim subjektima.

H8: *Između poduzetaca koja surađuju na razvoju inovacije i onih koja ne surađuju postoji razlika u utjecaju nedostatka kvalificiranog osoblja na inovacijske aktivnosti.*

Podaci korišteni za analizu su prikupljeni u sklopu projekta «Statistika inovacija u RH kao osnova za formuliranje znanstveno-tehnološke politike i evaluaciju konkurentnosti hrvatskih poduzeća», provedenog 2004. godine na Ekonomskom institutu u Zagrebu. Istraživanje je temeljeno na metodologiji *Community Innovation Survey 3* koja se koristi za istraživanje inovacijskih aktivnosti u zemljama Europske unije i zemljama kandidatkinjama za članstvo. Poštanskom su anketom prikupljeni podaci o inovacijskim aktivnostima hrvatskih poduzeća u razdoblju od 2001. do 2003. godine.

Iz baze su korišteni podaci prikladni potrebama ovog istraživanja. Kao uzorak su izdvojena samo inovativna poduzeća, točnije poduzeća koja su u razdoblju od 2001. do 2003. godine razvila i na tržište ponudila bilo koju vrstu inovacije proizvoda, bilo da se radi o inkremenatalnim ili radikalnim inovacijama. S obzirom na cilj istraživanja, korištena je diskriminacijska analiza.

Isključene su sve atipične vrijednosti čija bi se prisutnost mogla odraziti na rezultate analize. Naime, diskriminacijska je analiza izuzetno osjetljiva na postojanje atipičnih vrijednosti, odnosno kršenje pretpostavke o normalnoj distribuciji zbog atipičnih vrijednosti. Iako se u literaturi ističe da analiza nije izrazito osjetljiva na manje kršenje pretpostavke postojanja normalne distribucije (Klecka, 1980 prema Garson, 2007), njeno kršenje zbog postojanja atipičnih vrijednosti se snažno odražava na značajnost modela (Tabachnick i Fidell, 1996 prema Garson, 2007). U konačnici, veličina uzorka je 72 te je u skladu s preporučenom veličinom uzorka koji mora biti barem četiri ili pet puta veća od broja nezavisnih varijabli, kojih je u ovom slučaju osam.

Korištena je dvogrupna diskriminacijska analiza u kojoj prvu grupu čine poduzeća koja su ostvarila neki oblik ugovorne suradnje s drugim subjektima, dok drugu grupu čine poduzeća koja u razdoblju od 2001. do 2003. nisu razvijala inovacije u suradnji s drugim poduzećima. Zavisna varijabla predstavlja pravu dihotomiju, tj. grupe su međusobno isključive pa jedna jedinica može pripadati samo jednoj grupi. Od ukupno 72 jedinice u uzorku, 22 (ili 30,5 posto ukupnog uzorka) pripadaju u skupinu poduzeća koja su ostvarila ugovornu suradnju s drugim subjektima, dok ih je 50 u drugoj skupini. Dakle, prva je skupina znatno manja od druge, no ta razlika nije tolika da bi onemogućila primjenu diskriminacijske analize (Garson, 2007). S obzirom na prethodne empirijske nalaze o slaboj suradnji hrvatskih poduzeća na razvoju inovacija, ovakav omjer odgovara stvarnoj situaciji.

4. Rezultati istraživanja

Jedna od pretpostavki za primjenu diskriminacijske analize odnosi se na postojanje multikolinearnosti među nezavisnim varijablama. Prije provođenja

diskriminacijske analize ispitano je njeno postojanje među osam nezavisnih varijabli. U tablici 1 prikazana je matrica prosječnih korelacija unutar grupa. Rezultati ne upućuju na postojanje multikolinearnosti (svi koeficijent korelacije su manji od 0,8).

Tablica 1. **Prosječne korelacije unutar grupa među nezavisnim varijablama**

[illegible]

Izvor: Izračun autorice.

U prvoj fazi diskriminacijske analize utvrđeno je koliko su nezavisne varijable sposobne diskriminirati grupe. U tu je svrhu korištena fazna analiza, odnosno *forward stepwise* metoda kojom se postupno dodaju varijable u model dok se ne postignu zadovoljavajući kriteriji. U analizi su korištene vrijednosti F za ulaz = 2 i F za izlaz = 1.

Zaključci o značajnosti modela doneseni su na temelju poopćenog Wilksovog lambda testa koji se obično koristi u diskriminacijskoj analizi i koji predstavlja multivarijantni ekvivalent F-testa. Njegova vrijednost (0,68) upućuje na postojanje razlika između grupa, odnosno na to da dvije grupe imaju različite aritmetičke sredine.

Takav model sačinjava pet varijabli koje imaju značajan utjecaj na razlikovanje između grupa. Prema vrijednosti Wilksove lambde za pojedine varijable utvrđen je doprinos svake pojedine varijable razlikovanju između grupa. Razlikovanju doprinose: nedostatak kvalificiranog osoblja, broj radikalnih

inovacija, iznos ukupnih ulaganja u istraživanje i razvoj, veličina poduzeća prema broju zaposlenih i tržišna orijentacija. Preostale tri varijable (broj inkrementalnih inovacija, previsoki troškovi inovacijskih aktivnosti i nedostatak odgovarajućih izvora financiranja) ne ulaze u model. Vrijednosti tolerancije za svaku od pet varijabli u modelu pokazuju da niti jedna nije suvišna. U tablici 2 prikazane su varijable koje najbolje odražavaju razlike između dviju skupina, dok su u tablici 3 navedene varijable koje nisu ušle u model.

Tablica 2. Varijable u modelu						
	Wilksova lambda	Parcijalna Wilksova lambda	F za izlaz	p	Tolerancija	R ²
Nedostatak kvalificiranog osoblja	0,77	0,86	10,54	0,002	0,93	0,075
Broj radikalnih inovacija	0,78	0,87	9,67	0,003	0,93	0,071
Ulaganja u istraživanje i razvoj	0,77	0,88	9,15	0,004	0,63	0,372
Broj zaposlenih	0,73	0,93	5,18	0,026	0,69	0,309
Indeks tržišne orijentacije	0,72	0,94	4,47	0,038	0,84	0,156

Izvor: Izračun autorice.

Tablica 3. Varijable koje su izostavljene iz modela						
	Wilksova lambda	Parcijalna Wilksova lambda	F za ulaz	p	Tolerancija	R ²
Broj inkrementalnih inovacija	0,68	0,998	0,16	0,695	0,92	0,077
Previsoki troškovi inovacijskih aktivnosti	0,67	0,982	1,16	0,286	0,74	0,264
Nedostatak odgovarajućih izvora financiranja	0,68	0,997	0,18	0,678	0,88	0,163

Izvor: Izračun autorice.

S obzirom da se radi o dvogrupnoj analizi, izvedena je jedna diskriminacijska funkcija. Evaluacija funkcije prema prosjeku kanoničkih varijabli pokazuje da veći doprinos kanoničkoj funkciji ima skupina poduzeća koja ne surađuju. Dakle, funkcija stvara razliku između poduzeća koja ne surađuju i onih koja

za potrebe inovacijskih aktivnosti uspostavljaju suradnju s drugim subjektima (tablica 4).

Poduzeća koja surađuju	-1,02
Poduzeća koja ne surađuju	0,45

Izvor: Izračun autorice.

Diskriminacijska je funkcija općenito značajna na razini $p < 0,05$. Vrijednost Wilksove lambde (0,68) upućuje na postojanje razlika između grupa, odnosno na utjecaj varijabli modela na razlikovanje između grupa. Svojevrsna vrijednost diskriminacijske funkcije iznosi 0,48 i upućuje na značaj dimenzija za klasificiranje zavisne varijable. Kanonička korelacija iznosi 0,57 iz čega se zaključuje da postoji korelacija između diskriminacijske funkcije i dviju grupa. Hi-kvadrat test za kanoničku funkciju prikazan je u tablici 5.

Svojstvena vrijednost	0,48
Kanonička korelacija	0,57
Wilksova lambda	0,68
Hi-kvadrat	26,24
Stupnjevi slobode	5
Razina značajnosti	0,00008

Izvor: Izračun autorice.

U tablici 6 su prikazane vrijednosti standardiziranih i strukturnih koeficijenata pomoću kojih je konstruirana diskriminacijska funkcija. Strukturni koeficijenti su pouzdaniji pokazatelj relativne jakosti diskriminacijskih varijabli (Klecka, 1980 prema Ndubisi i Wah, 2004) zbog čega su korišteni za kreiranje diskriminacijske funkcije. Standardizirani koeficijenti služe za ocjenu jedinstvenog doprinosa nezavisne varijable diskriminacijskoj funkciji.

Tablica 6. Standardizirani i strukturni koeficijenti		
	Standardizirani koeficijent	Strukturni koeficijent
Nedostatak kvalificiranog osoblja	0,68	0,56
Broj radikalnih inovacija	-0,65	-0,51
Ulaganja u istraživanje i razvoj	-0,78	-0,25
Broj zaposlenih	0,57	0,08
Indeks tržišne orijentacije	0,48	0,09

Izvor: Izračun autorice.

Prema vrijednostima strukturnih koeficijenata može se zaključiti da izostanku suradnje između poduzeća i drugih subjekata najviše doprinosi nedostatak kvalificiranog osoblja. Veličina poduzeća prema broju zaposlenih i indeks tržišne orijentacije također doprinose izostanku suradnje, ali je njihov utjecaj znatno slabiji. S druge strane, broj radikalnih inovacija i visina ulaganja u istraživanje i razvoj su varijable koje najviše doprinose uspostavljanju suradnje na razvoju inovacije proizvoda.

Dakle, hrvatska poduzeća koja ne surađuju s drugim subjektima u razvoju inovacija proizvoda su poduzeća u kojima je snažan otežavajući faktor za provođenje inovacijskih aktivnosti nedostatak kvalificiranog osoblja. Oni također imaju veći broj zaposlenika i veći indeks tržišne orijentacije. Ta poduzeća manje razvijaju radikalne inovacije te manje ulažu u istraživanje i razvoj. Poduzeća koja uspostavljaju suradnju s drugim subjektima za potrebe razvoja inovacija proizvoda razvijaju inovacije višeg stupnja novosti, tj. radikalne inovacije, te ulažu visoke iznose u istraživanje i razvoj. Ova poduzeća imaju manji broj zaposlenih, ali nedostatak kvalificiranog osoblja ne predstavlja značajnu smetnju njihovim inovacijskim aktivnostima. Ona također imaju manji indeks tržišne orijentacije.

Nakon što je utvrđeno da navedene varijable stvaraju razliku između grupa poduzeća, prelazi se na klasifikaciju poduzeća. Dobivene su dvije klasifikacijske funkcije prikazane u tablici 7. Kako je već navedeno, broj jedinica u svakoj pojedinoj grupi je različit. Naime, više je poduzeća u skupini onih koja ne surađuju. Imajući na umu rezultate istraživanja o suradnji u hrvatskim poduzećima (Račić, Radas i Rajh, 2004), može se pretpostaviti da njihov omjer

odgovara stvarnoj situaciji u uzorku. Zbog toga je *a priori* vjerojatnost u klasifikacijskim funkcijama određena proporcionalno veličinama grupa (31:69).

	Poduzeća koja surađuju <i>a priori</i> p = 0,31	Poduzeća koja ne surađuju <i>a priori</i> p = 0,69
Nedostatak kvalificiranog osoblja	2,784	3,840
Broj radikalnih inovacija	0,458	-0,166
Ulaganja u istraživanje i razvoj	-0,0005	-0,0008
Broj zaposlenih	0,004	0,0065
Indeks tržišne orijentacije	15,617	16,915
Konstantni član	-34,756	-38,909

Izvor: Izračun autorice.

Iz klasifikacijske je matrice vidljivo kako su poduzeća iz uzorka raspoređena prema skupinama. Ukupno je 69,62 posto poduzeća raspoređeno prema očekivanoj klasifikaciji. 85,45 posto poduzeća iz skupine koja ne surađuje je dobro klasificirano dok je 33,33 posto onih koji surađuju raspoređeno u skladu s očekivanjima. Klasifikacijska je matrica prikazana u tablici 8.

	Postotak dobro raspoređenih	Poduzeća koja surađuju	Poduzeća koja ne surađuju
Poduzeća koja surađuju	33,33	8	16
Poduzeća koja ne surađuju	85,45	8	47
Ukupno	69,62	16	63

Izvor: Izračun autorice.

5. Zaključak

S ciljem utvrđivanja kombinacije varijabli na temelju kojih se može predvidjeti suradnja poduzeća s drugim subjektima za potrebe razvoja inovacija proizvoda, provedena je diskriminacijska analiza. Za početni skup od osam varijabli, analiza je pokazala da njih pet značajno doprinosi razlikovanju između grupa. One su: nedostatak kvalificiranog osoblja, broj radikalnih

inovacija, visina ulaganja u istraživanje i razvoj, broj zaposlenih i tržišna orijentacija. Prema tome, hipoteze H2, H3, H4, H5 i H8 se prihvaćaju.

S druge strane, hipoteze H1, H6 i H7 se odbacuju. Naime, rezultati diskriminacijske analize su pokazali da varijable: broj inkrementalnih inovacija, visoki troškovi inovacijskih aktivnosti i nedostatak odgovarajućih izvora financiranja ne doprinose diskriminiranju između skupine poduzeća koja ne surađuje na razvoju inovacija s drugim subjektima i onih koja surađuju.

Izostanku suradnje najviše doprinosi izražen problem nedostatka kvalificiranog osoblja za potrebe razvoja inovacije. Iako se može očekivati da poduzeća koja se suočavaju s problemom nedostatka kvalificiranog osoblja za potrebe razvoja inovacija, rješenje tog problema mogu naći u suradnji s drugim subjektima, pokazalo se kako je upravo nedostatak kvalificiranog osoblja veliki problem za uspostavljanje suradnje. Drugim riječima, takvim poduzećima ujedno nedostaje zaposlenika koji bi bili sposobni ostvariti suradnju. Ovaj je nalaz u skladu sa zaključcima do kojih je došla Radas (2005) koja je pokazala kako u hrvatskim poduzećima koja imaju iskusne i sposobne zaposlenike postoji intenzivnija suradnja između poduzeća i znanstvenih institucija.

Zaključak da poduzeća koja ne surađuju ujedno razvijaju manji broj radikalnih inovacija u skladu je s polaznom pretpostavkom i dosadašnjim spoznajama iz literature. Manja sklonost razvoju radikalnih inovacija smanjuje potrebu poduzeća da inovacije razvijaju u suradnji s drugim subjektima, s obzirom da inkrementalne inovacije ne zahtijevaju značajna sredstva i sposobnosti.

Što se tiče ulaganja u istraživanje i razvoj, pokazalo se da je ova varijabla prediktor suradnje pri čemu se poduzeća čija su ulaganja u istraživanje i razvoj veća, češće upuštaju u suradnju s drugim subjektima. Poduzeća koja više ulažu u istraživanje i razvoj, veliku važnost pridaju inovacijama i spremna su razvijati ih u suradnji s drugim poduzećima.

Poduzeća koja ne uspostavljaju suradnju, prema rezultatima diskriminacijske analize, imaju veći broj zaposlenih. Unatoč veličini, takva poduzeća ne

U svrhu testiranja rezultata diskriminacijske analize, dobiveni je model potrebno testirati na novom skupu podataka čime bi se doprinijelo pouzdanosti modela. Naime, točnost predviđanja testirana je na temelju istih podataka iz kojih je izvedena i diskriminacijska funkcija što treba imati na umu pri tumačenju rezultata istraživanja. Takva klasifikacija omogućava identificiranje slučajeva koji odstupaju od izvedene funkcije, dok klasifikacija na novim slučajevima ocjenjuje stvarnu snagu klasifikacijskih funkcija kada se radi o predviđanju pripadnosti pojedinoj skupini.

Privredna kretanja i ekonomska politika 111 / 2007. 65

Literatura

Abernathy, William J. i Kim B. Clark, 1985, «Mapping the Winds of Creative Destruction,» *Research Policy*, 14, str. 3-12.

Afuah, Allan, 2003, *Innovation Management*, Oxford: Oxford University Press.

Dodgson, Mark, 1992, «Technological Collaboration: Problems and Pitfalls,» *Technology Analysis and Strategic Management*, 4(1), str. 83-87.

Garson, David G., 2007, «Discriminant Function Analysis,» Statnotes: Topics in Multivariate Analysis,
<http://www2.chass.ncsu.edu/garson/pa765/statnote.htm> (pristupljeno 10. 4. 2007.).

Henderson, Rebecca M. i Kim B. Clark 1990, «Architectural Innovation: The Reconfiguration of Existing Product Technologies and the Failure of Established Firms,» *Administrative Science Quarterly*, 35, str. 9-30.

Ndubisi, Nelson Oly i Kok Wah Chan, 2005, «Factorial and Discriminant Analyses of the Underpinnings of Relationship Marketing and Customer Satisfaction,» *International Journal of Bank Marketing*, 23(7), str. 542-557.

Narver, John C. i Stanley Slater, 1990, «The Effect of a Market Orientation on Business Profitability,» *Journal of Marketing*, 62, str. 20-35.

Prester, Jasna i Najla Podrug, 2006, «Manufacturing Innovation: Case of Croatia,» *The Business Review, Cambridge*, 5(2), str. 198-195.

Račić, Domagoj, Sonja Radas i Edo Rajh, 2004, «Innovation in Croatian Enterprises: Preliminary Findings from Community Innovation Survey,» u Željko Lovrinčević et al., eds., *Proceedings of 65th Anniversary Conference of the Institute of Economics, Zagreb*, Zagreb: Ekonomski institut, Zagreb, str. 403-427.

Radas, Sonja, 2005, «Collaboration between Industry and Science: Motivation Factors, Collaboration Intensity and Collaboration Outcome,» *Croatian Economic Survey*, 8, str. 11-31.

Roberts, Edward B. i Charles A. Berry, 1985, «Entering New Businesses: Selecting Strategies for Success,» *Sloan Management Review*, 26(3), str. 3-17.

Trott, Paul, 2005, *Innovation Management and New Product Development*, Englewood Cliffs, NJ.: Prentice Hall.

Von Hippel, Eric, 1987, «Cooperation between Rivals: Informal Know-How Trading,» *Research Policy*, 16, str. 291-302.